

HUMBOLDT-UNIVERSITÄT ZU BERLIN
MATHEMATISCH-NATURWISSENSCHAFTLICHE FAKULTÄT
INSTITUT FÜR INFORMATIK

Klassifikation von Fehlerarten bei Schweißpunkten in der Industrie

Exposé
Studienprojekt

eingereicht von: Frank Hachenberger

geboren am: 29.02.2000

geboren in: Berlin

Betreuer/innen: Dr. Patrick Schäfer (Humboldt Universität zu Berlin)
Hendrik Schulz, M. Sc. (Mercedes-Benz AG)

Inhaltsverzeichnis

1	Motivation	1
2	Problemstellung	1
3	Zielsetzung	2
3.1	Stand der Forschung	2
3.2	Forschungsfrage	3
3.3	Methodische Herausforderungen	4
4	Daten	4

1 Motivation

Die Automobilindustrie ist ein zentraler und hochinnovativer Wirtschaftszweig Deutschlands, in dem die kontinuierliche Weiterentwicklung von Fertigungsprozessen und die Sicherstellung höchster Qualitätsstandards von entscheidender Bedeutung sind. Innerhalb dieses Sektors nimmt das Widerstandspunktschweißen (Resistance Spot Welding, RSW) eine herausragende Stellung ein. Es ist die primäre Fügetechnologie für über 90% der Verbindungen in einer Fahrzeugkarosserie, wobei typischerweise zwischen 4000 und 6000 Schweißpunkte pro Fahrzeug gesetzt werden [1, 3, 10]. Die Qualität jedes einzelnen Schweißpunkts ist von großer Wichtigkeit für die strukturelle Integrität, die Sicherheit und die Gesamthaltbarkeit des Endprodukts [3].

Trotz seiner weitreichenden Anwendung und der fortschreitenden Automatisierung bleibt RSW ein hochkomplexer, nichtlinearer und inherant instabiler Prozess [1, 3, 11]. Faktoren wie Elektrodendegradation [6], Materialvariationen [3], Oberflächenverunreinigungen oder Montagefehler können zu unerwünschten Defekten führen, die die Schweißpunktqualität beeinträchtigen [1, 9]. Traditionelle Qualitätskontrollmethoden, die auf zeitaufwändigen manuellen Offline-Stichprobenprüfungen basieren, sind nicht nur zeitaufwendig und kostspielig, sondern auch fehleranfällig und können keine 100%ige Inspektion gewährleisten [3]. Dies unterstreicht die dringende Notwendigkeit effizienter, präziser und vor allem online durchführbarer Inspektionsverfahren [2, 3].

In den letzten Jahren haben Maschinelles Lernen (ML) und Deep Learning (DL) vielversprechende Ansätze zur Qualitätsüberwachung und Fehlererkennung im RSW-Prozess geboten, indem sie Sensordaten nutzen, um Muster automatisch zu identifizieren und die Beschränkungen der manuellen Merkmalsextraktion zu überwinden [1, 7]. Aktuelle Forschungsarbeiten konzentrieren sich jedoch häufig auf die Vorhersage allgemeiner Qualitätsparameter wie den Punktdurchmesser oder die Schweißfestigkeit [9, 10] und klassifizieren Schweißpunkte in der Regel in eine begrenzte Anzahl von Kategorien. Beispielsweise werden oft nur "gut", "Kaltschweißung" (cold weld) und "Durchbrand" (expulsion/burn-through) unterschieden [2, 9, 11]. Darüber hinaus stützen sich viele dieser Studien auf Datensätze, die in kontrollierten Laborumgebungen oder aus öffentlich zugänglichen Quellen stammen, welche möglicherweise nicht die volle Komplexität und Variabilität realer Produktionslinien widerspiegeln [3, 4].

2 Problemstellung

Trotz erheblicher Fortschritte in der ML-basierten Qualitätskontrolle existieren in der aktuellen Forschung und industriellen Praxis noch immer wesentliche Defizite, die die Übertragbarkeit auf reale Produktionsszenarien erschweren. Ein zentrales Problem ist die begrenzte Fehlerklassifikation. Die meisten bestehenden Forschungsarbeiten konzentrieren sich auf die Erkennung von lediglich zwei bis drei Fehlerkategorien oder clustern die spezifischen Fehlertypen auf einige wenige Fälle. Allerdings sind spezielle Fehlerarten wie

„Durchbrand“ oder „kleine Linse“ von sehr großer Bedeutung, da sie erhebliche Kosten verursachen und extrem kritisch für die Produktion sind. Die vorliegenden disjunkten Fehlerklassen erfordern dabei einen Klassifikationsansatz zur eindeutigen Fehlerzuordnung.

Ein weiteres signifikantes Problem ist die unzureichende Berücksichtigung von Klassenungleichgewichten. In realen Produktionsdaten sind fehlerfreie Schweißpunkte stark überrepräsentiert, während kritische Fehler nur selten auftreten. Dieses extreme Ungleichgewicht wird von aktuellen Modellen oft nicht angemessen berücksichtigt, was zu einer verzerrten Auswertung führen kann.

3 Zielsetzung

Das Ziel dieser Studienarbeit ist die Untersuchung der Eignung unterschiedlicher überwachter Methoden als effiziente Alternativen zu etablierten ML-Verfahren (wie Random Forest oder XGBoost) für multivariate Zeitreihen in der Qualitätskontrolle des Widerstandspunktschweißens. Im Mittelpunkt steht ein systematischer Vergleich kernelbasierter, intervallbasierter, DL- und Foundation-Modelle zur Fehlerklassifikation unter produktionsnahen Bedingungen. Die Arbeit adressiert bestehende Forschungslücken und leitet praxisnahe Empfehlungen für den industriellen Einsatz ab.

3.1 Stand der Forschung

Die Arbeit von Ruiz et al. (2021) [8] befasst sich mit der Problemstellung der unzureichenden Vergleichbarkeit von Algorithmen in der multivariaten Zeitreihenklassifikation (MTSC) aufgrund fehlender standardisierter Datensätze. Das Ziel ist es, die relative Leistung bestehender MTSC-Algorithmen auf einer breiteren Basis zu bewerten und Empfehlungen für Anwendende zu geben. Als Methodik verwenden sie über 20 gleich lange Datensätze aus dem UEA MTSC Archiv und verglichen verschiedene Algorithmen, darunter ResNet, MUSE, Varianten von Dynamic Time Warping (DTW) sowie ROCKET. ROCKET (*Random Convolutional Kernel Transform*) [5] verwendet Zehntausende zufällig parametrisierter 1D-Faltungskerne mit kanalspezifischen Gewichtungen, extrahiert aus den Filterantworten Merkmale wie das Maximum und den Anteil positiver Werte (*ppv*) und klassifiziert diese effizient mittels einem linearen Klassifikationsmodell. Die Ergebnisse zeigten, dass DTW zwar weiterhin gute Ergebnisse liefert, ROCKET jedoch die höchste Gesamtgenauigkeit erreicht und sich als bemerkenswert schnell erwies, was es zur empfohlenen Wahl macht. Die genutzten Daten aus dem UEA MTSC Archiv umfassen diverse reale Probleme mit unterschiedlichen Dimensionen und Längen.

Chang et al. (2023) [2] adressieren die Problemstellung der unzureichenden Echtzeitqualitätserkennung bei RSW in der Automobilproduktion, wo traditionelle manuelle Stichprobenprüfungen zu geringer Effizienz und hohen Kosten führen. Das Ziel ist die Entwicklung einer automatisierten Online-Erkennungsmethode für Schweißqualität mit

hoher Genauigkeit und Echtzeitfähigkeit. Die Methodik basiert auf einem kombinierten CNN-LSTM-Netzwerk mit Attention-Mechanismus zur Klassifikation von drei Qualitätskategorien (normal, Durchbrand, Kaltschweißung) aus dynamischen Strom- und Widerstandszeitreihen, wobei die eindimensionalen Strom- und Widerstandsdaten zu zweidimensionalen Zeitreihendaten fusioniert wurden und das extreme Klassenungleichgewicht durch SMOM-Oversampling und eine gewichtete Cross-Entropy-Loss-Funktion behandelt worden ist. Als Datenlage dienten 2.200 Schweißproben aus realer Automobilproduktion (2.000 normale, je 100 fehlerhafte) mit 1 kHz-Abtastrate von Strom- und Widerstandssensoren. Die Ergebnisse zeigen eine Gesamtklassifikationsgenauigkeit von ungefähr 98,5% mit Precision- und Recall-Werten über 95% für alle Fehlerarten bei einer Inferenzzeit von 7,3 ms.

Die Arbeit von Chuenmee et al. (2025) [3] befasst sich mit der geringen Inspektionsabdeckung (nur 5 %) von RSW in der Automobilindustrie, die traditionell auf manuellen Prüfungen basieren, was hohe Kosten und unzureichende Informationen verursacht. Das Hauptziel dieser Arbeit war es, die Prüfabdeckung auf 100% zu erhöhen und die Schweißqualität (zufriedenstellend, Auswurf, Kaltverschweißung) mittels ML genau vorherzusagen. Als Methodik wurde die Ultraschallprüfung (UT) zur Klassifizierung der Schweißqualität eingesetzt, wobei Daten aus Laborexperimenten und einer realen Produktionslinie gesammelt wurden. Aus den insgesamt 410 effektiven Schweißdatensätzen wurden 29 relevante physikalische Merkmale, basierend auf Zeitreihen von Spannung, Strom und Widerstand, extrahiert und verschiedene Modelle (ANN, CNN, LSTM, RFC, XGBoost) evaluiert. Dabei zeigte sich das entwickelte XGBoost-Modell mit einer Testgenauigkeit von rund 98% und einem F1-Score von etwa 97% als das beste für die Vorhersage der Schweißqualität.

3.2 Forschungsfrage

Im Hinblick auf die gegenwärtigen Herausforderungen in der industriellen Schweißpunktprüfung wird die folgende zentrale Forschungsfrage untersucht:

Welche Modellarchitektur erzielt bei der Fehlerklassifikation auf multivariaten Zeitreihen des Widerstandspunktschweißens die beste Performance über Schweißpunkte hinweg?

Zur Beantwortung dieser Forschungsfrage werden balancierte und unbalancierte Datensätze sowie verschiedene Stichprobengrößen erstellt und folgende Hypothesen formuliert:

- H1:** Für kritische Fehlerklassen (wie offen/lose/kleine Linse oder Durchbrand) erzielen DL/Foundation Modelle auf balancierten wie unausgeglichenen Datensätzen die höchsten F1- und AUC-Werte.
- H2:** Mit wachsender Stichprobe steigt F1 (macro) und AUC bei DL/Foundation Modelle stärker als die von kernel-/intervallbasierten Verfahren.

H3: Der Abfall von F1 (macro) und AUC gegenüber den Datensätzen basierend auf dem Rohdatensatz stärker als in den Clusterbasierten Datensätze über alle Modelle hinweg.

H4: Kernel-/intervallbasierte Verfahren weisen die geringste Trainings- und Inferenzzeit sowie den niedrigsten Speicherverbrauch (Peak-RAM/GPU, Modellgröße) auf.

3.3 Methodische Herausforderungen

Die Arbeit steht vor mehreren methodischen Herausforderungen, die aus realen Produktionsbedingungen resultieren. Eine wesentliche Problematik besteht in der ausgeprägten Variabilität der Zeitreihensignaturen über unterschiedliche Schweißpunkte und Produktionsanlagen hinweg. Diese Heterogenität birgt das Risiko, dass Modelle schweißpunkt- oder anlagenspezifische Artefakte anstelle generalisierender Prozessmerkmale erlernen. Es gilt daher, geeignete Strategien zur Bias-Minimierung zu entwickeln und deren Wirksamkeit durch robuste Validierungsverfahren nachzuweisen. Parallel sind je vorgesehenem Architekturtyp die konkreten Modelle zu bestimmen und in einem einheitlichen Vergleichsrahmen zu betrachten. Zudem ist die Skalierbarkeit der Datensätze zu prüfen, indem abgestufte Datenumfänge definiert und die Entwicklung zentraler Leistungs- und Ressourcenkennzahlen über diese Stufen hinweg nachvollzogen wird.

4 Daten

Die Grundlage dieser Studienarbeit bildet die umfangreiche Mercedes-Benz Datenbasis aus dem Produktionswerk Sindelfingen, die einen außergewöhnlich wertvollen und repräsentativen Datensatz für die industrielle Schweißqualitätskontrolle darstellt. Dieser Datensatz dokumentiert reale Produktionsbedingungen über einen Zeitraum von Januar 2024 bis März 2025 und umfasst insgesamt 260.000 Schweißungen, von denen 28.000 als qualitativ nicht ausreichend klassifiziert wurden. Die Daten stammen von ungefähr 2.000 verschiedenen Schweißpunkten und dokumentieren 10 unterschiedliche Fehlerarten, was eine wesentlich differenziertere Fehlerklassifikation ermöglicht als in bisherigen Studien. Die Klassifikation der Schweißpunkte erfolgt durch manuelle Bewertung von Ultraschallmessbildern durch geschulte Fachkräfte, wobei das potenzielle Vorhandensein von False Negatives nicht vollständig ausgeschlossen werden kann.

Jeder Schweißvorgang wird durch hochfrequente Messwerte der Spannung, des Stroms und der Kraft während der charakteristischen RSW-Phasen (Squeeze-, Weld-, Hold- und Off-time) vollständig charakterisiert, wodurch eine umfassende multivariate Zeitreihenanalyse zur Qualitätsbewertung möglich wird. Im Folgenden werden die einzelnen Phasen anhand der Abb. 1 beschrieben:

- **Squeeze Time (Klemmzeit):** Dies ist die Anfangsphase, in der die Elektrodenkraft angelegt wird, um die Werkstücke fest zusammenzudrücken.

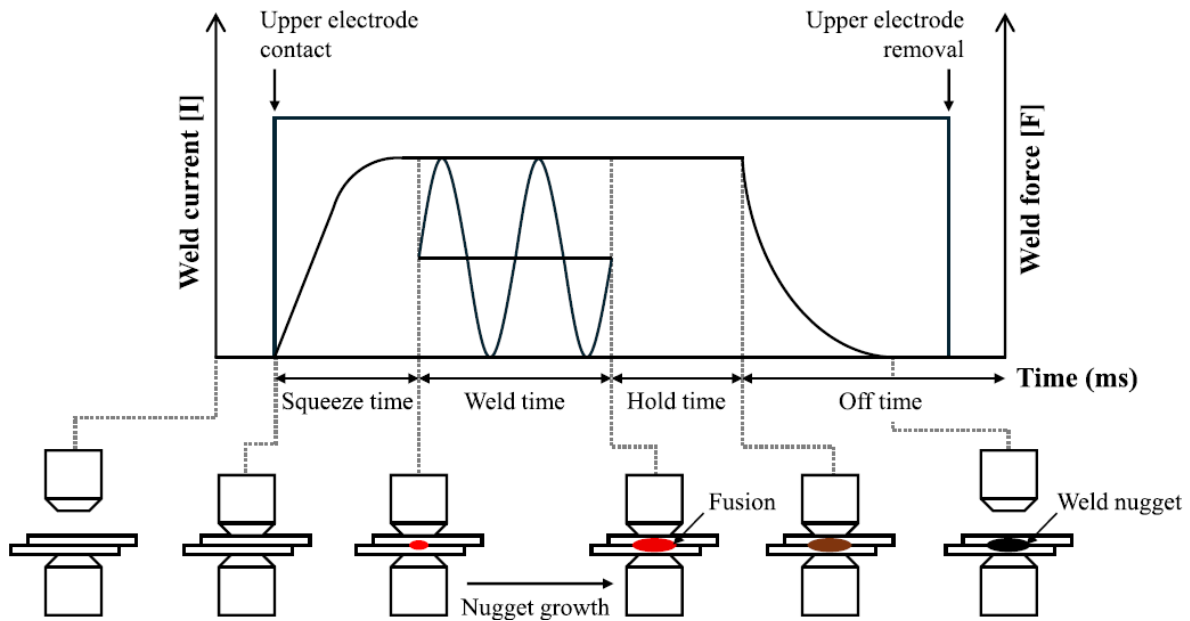


Abbildung 1: Typische Zeitreihe von RSW [3]

- **Weld Time (Schweißzeit):** In dieser Phase wird der Schweißstrom auf das Werkstück angewendet. Das Material erhitzt sich und schmilzt, wodurch der Schweißnugget oder Schweißlinse entsteht.
- **Hold time (Haltezeit):** Nach dem Abschalten des Schweißstroms wird die Schweißkraft aufrechterhalten, damit der Schweißnugget erstarren kann, bevor die Teile freigegeben werden. Das Metall kühlt ab und zieht sich zusammen, wodurch die Kraft- und Wegkurven tendenziell abfallen.
- **Off Time (Pausenzeit):** Dies ist die Zeitspanne, in der die Elektroden während eines sich wiederholenden Schweißzyklus keinen Kontakt mit dem Werkstück haben. Sie ist notwendig, um das Werkstück zwischen den Schweißsequenzen zu bewegen.

Literatur

- [1] S. Abd Halim, Y. H. P. Manurung, M. A. Raziq, C. Y. Low, M. S. Rohmad, J. R. C. Dizon, and V. S. Kachinskyi. Quality prediction and classification of resistance spot weld using artificial neural network with open-sourced, self-executable and GUI-based application tool Q-Check. 13(1):3013.
- [2] F. Chang, G. Zhou, K. Ding, J. Li, Y. Jing, J. Hui, and C. Zhang. A CNN-LSTM and Attention-Mechanism-Based Resistance Spot Welding Quality Online Detection Method for Automotive Bodies. 11(22):4570.
- [3] N. Chuenmee, N. Phothi, K. Chamniprasart, S. Khaengkarn, and J. Srisertpol. Machine learning for predicting resistance spot weld quality in automotive manufacturing. 25:103570.
- [4] G. Ciravegna, F. Galante, D. Giordano, T. Cerquitelli, and M. Mellia. Fault Prediction in Resistance Spot Welding: A Comparison of Machine Learning Approaches. 13(18):3693.
- [5] A. Dempster, F. Petitjean, and G. I. Webb. ROCKET: Exceptionally fast and accurate time series classification using random convolutional kernels. 34(5):1454–1495.
- [6] D. Ibáñez, E. Garcia, J. Soret, and J. Martos. An Unsupervised Condition Monitoring System for Electrode Milling Problems in the Resistance Welding Process. 22(12):4311.
- [7] O. Martin, V. Ahedo, J. I. Santos, and J. M. Galan. Comparative Study of Classification Algorithms for Quality Assessment of Resistance Spot Welding Joints From Pre- and Post-Welding Inputs. 10:6518–6527.
- [8] A. P. Ruiz, M. Flynn, J. Large, M. Middlehurst, and A. Bagnall. The great multivariate time series classification bake off: A review and experimental evaluation of recent algorithmic advances. 35(2):401–449.
- [9] M. Russell, J. Kershaw, Y. Xia, T. Lv, Y. Li, H. Ghassemi-Armaki, B. E. Carlson, and P. Wang. Comparison and explanation of data-driven modeling for weld quality prediction in resistance spot welding. 35(3):1305–1319.
- [10] B. Zhou, T. Pychynski, M. Reischl, and R. Mikut. Comparison of Machine Learning Approaches for Time-series-based Quality Monitoring of Resistance Spot Welding (RSW).
- [11] K. Zhou and P. Yao. Overview of recent advances of process analysis and quality control in resistance spot welding. 124:170–198.